

Analisis Augmentasi Data untuk Klasifikasi Tuberkulosis Berbasis DenseNet121

Data Augmentation Analysis for Tuberculosis Classification Based on DenseNet121

Tiara Amanda Putri^{a,1}, Rudi Kurniawan^{a,2}, Bani Nurhakim^{b,3}, Nining Rahaningsih^{c,4}, Willy Prihartono^{c,5}

^a Teknik Informatika, STMIK IKMI Cirebon, Cirebon, Indonesia

^b Manajemen Informatika, STMIK IKMI Cirebon, Cirebon, Indonesia

^c Komputerisasi Akuntansi, STMIK IKMI Cirebon, Cirebon, Indonesia

*¹amandatiarap23@gmail.com, ²rudi226ikmi@gmail.com, ³baninurhakim@gmail.com, ⁴niningr157@yahoo.co.id,

⁵willyprihartono@gmail.com

*corresponding author

Informasi Artikel	ABSTRAK
<p>Diserahkan : 27 November 2025 Diterima : 27 Desember 2025 Direvisi : 10 Februari 2026 Diterbitkan : 28 Februari 2026</p> <p>Kata Kunci: Augmentasi Data Citra X-ray DenseNet121 Klasifikasi CXR Tuberkulosis</p>	<p>Tuberkulosis (TB) merupakan penyakit menular dengan beban kesehatan yang tinggi, sehingga deteksi dini menggunakan citra rontgen dada (Chest X-Ray/CXR) menjadi penting untuk mempercepat diagnosis dan mendukung pengendalian penyakit. Namun, keterbatasan jumlah data berlabel serta ketidakseimbangan kelas pada dataset publik menyebabkan model Deep Learning rentan mengalami <i>overfitting</i> dan kesalahan klasifikasi, terutama pada kelas minoritas. Penelitian ini bertujuan menganalisis efektivitas berbagai teknik augmentasi data dalam meningkatkan kinerja model DenseNet121 untuk klasifikasi TB pada citra X-ray paru. Arsitektur DenseNet121 dimodifikasi dengan penambahan fully connected layer dan dropout untuk meningkatkan kemampuan generalisasi serta mengurangi risiko <i>overfitting</i>. Penelitian menggunakan dataset Tuberculosis Chest X-Ray Kaggle yang terdiri dari 3.500 Citra Normal dan 700 citra TB. Tahapan penelitian meliputi <i>preprocessing</i> (normalisasi, resizing, konversi grayscale ke pseudo-RGB, dan segmentasi ROI paru), pembagian data dengan <i>stratified sampling</i> (70% pelatihan, 15% validasi, 15% pengujian), serta pelatihan model pada empat skenario: tanpa augmentasi, augmentasi geometrik, augmentasi intensitas, dan augmentasi lanjutan (MixUp, CutMix, Random Erasing). Evaluasi dilakukan menggunakan akurasi, presisi, recall, F1-score, AUROC, AUPRC, confusion matrix, Grad-CAM, Bootstrap Confidence Interval, dan uji McNemar. Hasil menunjukkan bahwa augmentasi lanjutan memberikan kinerja numerik terbaik dengan akurasi 98,57% dan F1-score 0,9569, namun perbedaan performa tidak signifikan pada $\alpha = 0,05$. Temuan ini menunjukkan bahwa meskipun meningkatkan performa secara empiris, augmentasi lanjutan memerlukan validasi eksternal skala besar untuk memastikan generalisasi yang lebih kuat.</p>
<p>Keywords: Chest X-ray DenseNet121 Data Augmentation Tuberculosis CXR Classification</p>	<p>ABSTRACT</p> <p><i>Tuberculosis (TB) is an infectious disease with a high health burden, so early detection using chest X-rays (CXR) is very important to speed up diagnosis and support disease control. However, the limited amount of labeled data and class imbalance in public datasets cause Deep Learning models to be prone to overfitting and classification errors, especially in minority classes. This study aims to analyze the effectiveness of various data augmentation techniques in improving the performance of the DenseNet121 model for TB classification in lung X-ray images. The DenseNet121 architecture was modified by adding a fully connected layer and dropout to improve generalization capabilities and reduce the risk of overfitting. This study uses the Tuberculosis Chest X-Ray Kaggle dataset, consisting of 3,500 normal images and 700 TB images. The research stages include preprocessing (normalization, size adjustment, grayscale to pseudo-RGB conversion, and lung ROI segmentation), data division with stratified sampling (70% training, 15% validation, 15% testing), and model training in four scenarios: without augmentation, geometric augmentation, intensity augmentation, and advanced augmentation (MixUp, CutMix, Random Erasing). The evaluation was conducted using accuracy, precision, recall, F1-score, AUROC, AUPRC, confusion matrix, Grad-CAM, Bootstrap Confidence</i></p>

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.



Interval, and McNemar's Test. The results show that advanced augmentation provides the best numerical performance with an accuracy of 98.57% and an F1 score of 0.9569, but the difference in performance is not significant at $\alpha = 0.05$. These findings indicate that although advanced augmentation empirically improves performance, advanced augmentation requires large-scale external validation to ensure stronger generalization.

I. Pendahuluan

Tuberkulosis (TB) merupakan penyakit menular dengan dampak besar terhadap kesehatan global, dengan lebih dari 10 juta kasus baru setiap tahun [1]. Metode diagnosis konvensional seperti pemeriksaan dahak dan uji laboratorium memiliki keterbatasan sensitivitas dan waktu proses, sehingga berpotensi menyebabkan keterlambatan penanganan [2]. Dalam konteks ini, teknologi *deep learning* berperan penting dalam analisis citra medis karena kemampuannya mengekstraksi fitur visual secara otomatis dan konsisten [3].

DenseNet121 merupakan salah satu arsitektur yang banyak digunakan pada klasifikasi citra medis karena konektivitas antarlapisan pada *dense block* mampu meningkatkan pemanfaatan fitur dan mengurangi risiko *vanishing gradient* [4]. Namun, pada klasifikasi TB berbasis citra X-ray, ketidakseimbangan kelas antara citra Normal dan TB serta keterbatasan data berlabel dapat memicu *overfitting* dan menurunkan kemampuan generalisasi model [5], [6].

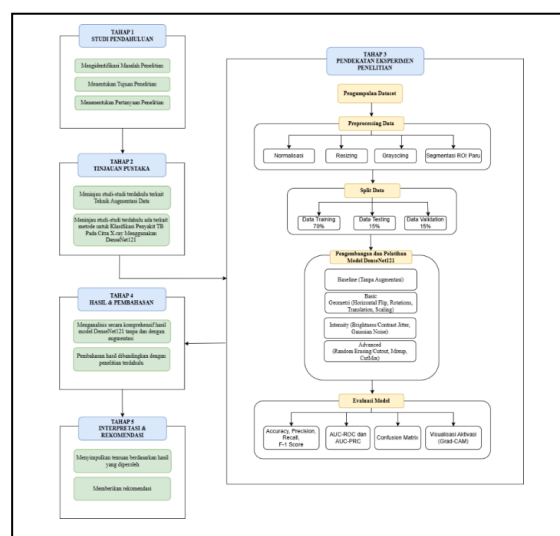
Augmentasi data menjadi pendekatan umum untuk meningkatkan keragaman data melalui transformasi geometrik dan intensitas, sehingga membantu model mempelajari representasi fitur yang lebih robust [7]. Beberapa penelitian melaporkan bahwa augmentasi mampu meningkatkan kinerja DenseNet121 dan model serupa pada klasifikasi citra medis [8], [9], [10], [11]. Namun, sebagian besar studi masih menerapkan satu atau dua jenis augmentasi dan belum melakukan perbandingan komprehensif antara augmentasi dasar dan augmentasi lanjutan seperti MixUp, CutMix, dan Random Erasing, khususnya pada kasus TB.

Oleh karena itu, penelitian ini bertujuan mengevaluasi secara sistematis pengaruh augmentasi geometrik, augmentasi intensitas, dan augmentasi lanjutan terhadap kinerja DenseNet121 dalam klasifikasi TB menggunakan citra X-ray. Evaluasi dilakukan menggunakan berbagai metrik kinerja serta uji statistik (Bootstrap CI dan McNemar) untuk menilai stabilitas dan signifikansi perbedaan hasil.

II. Metode

A. Jenis dan Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimen komparatif untuk mengevaluasi pengaruh berbagai teknik augmentasi data terhadap kinerja model DenseNet121 dalam klasifikasi citra X-ray Tuberculosis (TB). Pendekatan kuantitatif dipilih karena memungkinkan pengukuran performansi model secara objektif melalui metrik akurasi, presisi, recall, F1-score, AUC-ROC, dan AUC-PRC. Proses penelitian disusun melalui beberapa tahapan, meliputi studi pendahuluan, kajian literatur, perancangan eksperimen, pengembangan model, serta analisis hasil. Alur umum penelitian ditunjukkan pada Gambar 3.1.



Gambar 1. Desain Penelitian


Gambar 1 menyajikan alur penelitian secara keseluruhan, dimulai dari studi pendahuluan, kajian literatur, perancangan eksperimen, pengembangan model, hingga analisis hasil. Diagram ini menjadi dasar perencanaan eksperimen dan memastikan setiap tahapan berjalan sistematis dan terstruktur dalam mengevaluasi pengaruh teknik augmentasi data terhadap kinerja DenseNet121.

B. Subjek dan Objek Penelitian

Objek penelitian adalah citra X-ray TB dan Normal dari dataset Kaggle (4.200 citra; 3.500 Normal dan 700 TB). Subjek penelitian adalah model DenseNet121 (pretrained ImageNet) yang digunakan sebagai klasifikator.

C. Pengumpulan Data

Dataset mencakup citra X-ray berukuran 512×512 piksel dalam format JPG atau PNG dihimpun dari dataset Tuberculosis Chest X-Ray Kaggle. Setiap citra kemudian diperiksa kembali untuk memastikan kesesuaian label, kualitas visual, dan struktur anatomi yang utuh. Contoh representatif citra TB dan Normal ditampilkan pada Gambar 2 sebagai ilustrasi distribusi data.



Gambar 2. Sampel Data Citra TB dan Normal

D. Preprocessing Data

Tahap preprocessing data mencakup sejumlah proses penyesuaian citra untuk memastikan kompatibilitas dan kualitas input bagi model DenseNet121. Proses normalisasi dilakukan menggunakan pendekatan Min-Max scaling (mengubah nilai piksel ke rentang $[0, 1]$). Seluruh citra kemudian diubah ukurannya menjadi 224×224 piksel agar sesuai dengan ukuran input standar DenseNet121. Karena sebagian citra berbentuk grayscale, dilakukan konversi ke format pseudo-RGB melalui replikasi saluran warna. Selain itu, segmentasi ROI paru menggunakan mask paru diaplikasikan untuk menghilangkan area non-paru dan memfokuskan fitur pada struktur anatomi yang relevan.

E. Split Data

Tahap pembagian dataset dilakukan menggunakan stratified sampling, data dibagi menjadi tiga subset yaitu 70% untuk pelatihan, 15% untuk validasi, dan 15% untuk pengujian. Pembagian ini memastikan proporsi kelas TB dan Normal tetap konsisten pada setiap subset, sehingga memungkinkan proses pelatihan dan evaluasi dilakukan secara adil tanpa bias distribusi kelas.

F. Pengembangan dan Pelatihan Model DenseNet121

Model dikembangkan menggunakan arsitektur DenseNet121 dengan bobot pralatih ImageNet melalui pendekatan *transfer learning*. Seluruh lapisan fitur dipertahankan, sementara bagian classifier dimodifikasi menjadi *Global Average Pooling*, Dense 128 neuron (ReLU), dropout 0,5, dan output sigmoid untuk klasifikasi biner. Pelatihan dilakukan dengan optimizer Adam ($lr = 1e-4$), batch size 32, maksimum 30 epoch, serta *EarlyStopping* dan *ModelCheckpoint* untuk menjaga stabilitas dan mencegah overfitting.

G. Skenario Augmentasi

Penelitian ini menguji empat skenario augmentasi data untuk mengevaluasi pengaruh variasi transformasi citra terhadap kemampuan model dalam mengenali pola Tuberkulosis. Keempat skenario tersebut dirancang untuk mencerminkan tingkatan kompleksitas augmentasi, mulai dari tanpa augmentasi hingga teknik lanjutan yang menggabungkan beberapa citra secara sintetik.

1. Baseline, tanpa augmentasi, hanya preprocessing standar.
2. Geometric, rotasi kecil, translasi, zoom ringan, dan horizontal flip untuk menambah variasi posisi anatomi.
3. Intensity, variasi brightness-contrast dan Gaussian noise untuk meningkatkan ketahanan terhadap perbedaan kualitas pencitraan.
4. Advanced, MixUp, CutMix, dan Random Erasing yang menggabungkan atau menghapus sebagian area citra untuk meningkatkan generalisasi secara agresif.

Keempat skenario dirancang untuk merepresentasikan tingkat kompleksitas augmentasi dari konservatif hingga intensif.

H. Evaluasi Model

Kinerja model dinilai menggunakan akurasi, presisi, recall, dan F1-score sebagai metrik utama klasifikasi. AUROC dan AUPRC digunakan untuk menilai kemampuan pemisahan kelas pada data yang tidak seimbang. *Confusion matrix* dianalisis untuk melihat pola kesalahan model, sementara Grad-CAM digunakan untuk memverifikasi apakah fokus prediksi berada pada area paru yang relevan. Validasi statistik dilakukan menggunakan Bootstrap CI dan Uji McNemar untuk memastikan perbedaan performa antar skenario tidak terjadi secara acak.

III. Hasil dan Pembahasan

A. Hasil Penelitian

Penelitian ini menguji empat skenario augmentasi data (baseline, geometric, intensity, dan advanced) untuk mengevaluasi pengaruhnya terhadap kinerja model DenseNet121 dalam klasifikasi citra X-ray Tuberkulosis. Seluruh model dilatih menggunakan konfigurasi hyperparameter yang sama agar perbandingan lebih objektif.

B. Hasil Kinerja Model

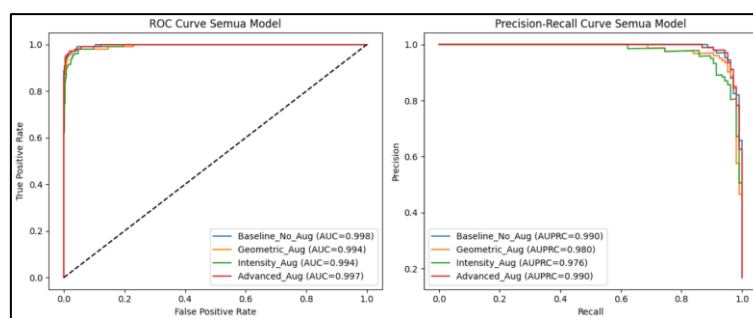
Secara keseluruhan, seluruh model menunjukkan performa tinggi dengan akurasi di atas 95%. Skenario advanced augmentation menghasilkan kinerja terbaik dengan akurasi 98.57%, precision 0.9572, recall 0.9566, dan F1-score 0.9569. Skenario baseline berada di urutan kedua dengan akurasi 98.26%, sedangkan skenario geometric mencapai akurasi 97.14%. Skenario intensity menunjukkan performa lebih rendah, terutama pada recall, akibat adanya augmentasi brightness-contrast dan Gaussian noise yang menyebabkan hilangnya pola patologis halus. Ringkasan performa keempat skenario disajikan pada Tabel 1.

Tabel 1. Ringkasan Kinerja Model pada Empat Skenario Augmentasi

Model	Accuracy	Precision	Recall	F1-Score
Baseline No Aug	0.982567	0.943925	0.952830	0.948357
Geometric Aug	0.979398	0.934579	0.943396	0.938967
Intensity Aug	0.973059	0.932039	0.905660	0.918660
Advanced Aug	0.985737	0.970874	0.943396	0.956938

C. Analisis AUROC dan AUPRC

Evaluasi area under curve menunjukkan pola serupa. Skenario advanced menghasilkan nilai AUROC 0.993 dan AUPRC 0.986, tertinggi di antara empat model. Skenario baseline dan geometric menunjukkan performa sangat baik (AUROC > 0.98), sedangkan skenario intensity menurun menjadi 0.974. Kurva AUROC/AUPRC seluruh model berada pada rentang sangat tinggi (>0.97), menandakan kemampuan diskriminatif yang baik.



Gambar 3. Kurva AUROC & AUPRC Semua Model

Untuk memberikan gambaran numerik yang lebih terperinci, nilai AUROC dan AUPRC masing-masing model dirangkum dalam Tabel 2 Hasil AUROC dan AUPRC Semua Model.

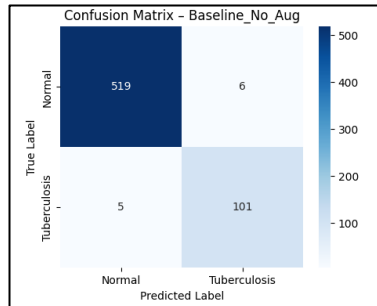
Tabel 2. Hasil AUROC dan AUPRC Semua Model

Model	AUROC	AUPRC
Baseline No Aug	0.9975	0.9901
Geometric Aug	0.9944	0.9803
Intensity Aug	0.9939	0.9760
Advanced Aug	0.9974	0.9901

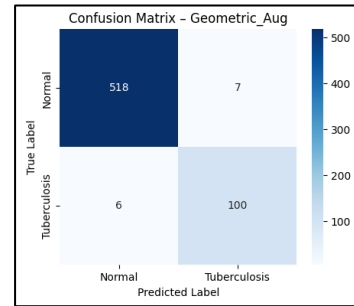
Nilai AUPRC secara khusus menegaskan keunggulan skenario advanced, mengingat AUPRC lebih sensitif terhadap ketidakseimbangan data. Hasil ini menunjukkan bahwa augmentasi kompleks seperti MixUp dan CutMix dapat meningkatkan konsistensi pemisahan kelas bahkan ketika proporsi kelas tidak seimbang.

D. Analisis Confusion Matrix

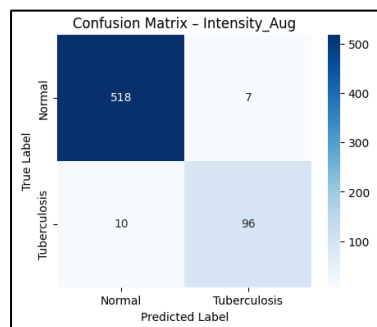
Analisis confusion matrix memberikan gambaran lebih detail mengenai pola kesalahan pada setiap skenario. Model baseline melakukan kesalahan paling sedikit pada kelas Normal (Gambar 4), sedangkan skenario geometric dan intensity cenderung melakukan lebih banyak false negative, yang berpotensi berbahaya dalam konteks diagnosis TB (Gambar 5 dan 6). Skenario advanced menunjukkan peningkatan signifikan dalam mengurangi false negative dibandingkan skenario lainnya (Gambar 7). Hal ini menandakan bahwa teknik MixUp, CutMix, dan Random Erasing membantu model menjadi lebih toleran terhadap variasi citra dan mengurangi ambiguitas dalam pengenalan pola patologis.




Gambar 4. Confusion Matrix (Baseline)



Gambar 5. Confusion Matrix (Geometric)



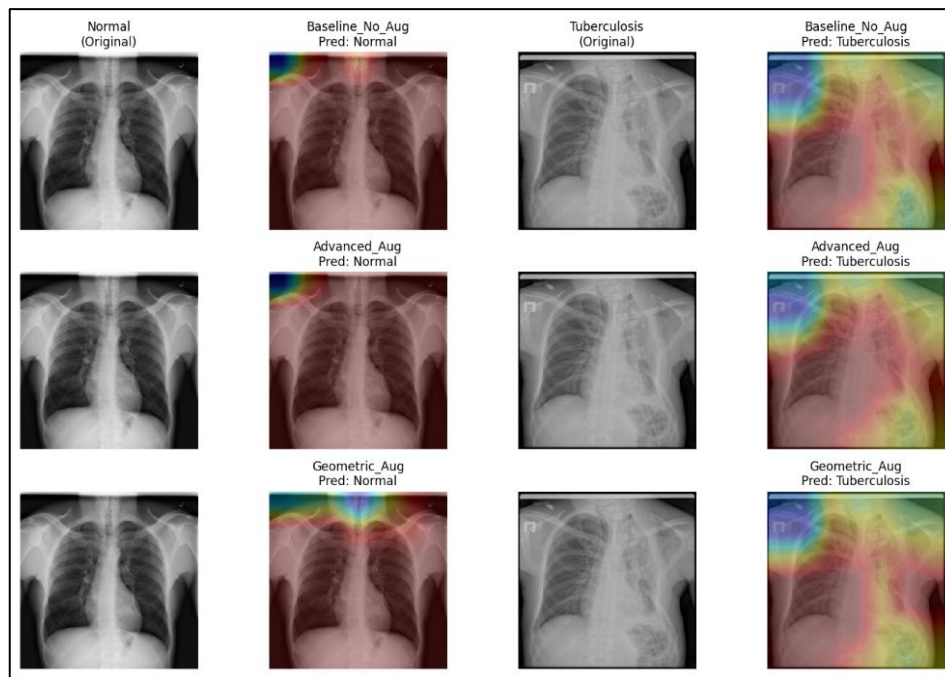
Gambar 6. Confusion Matrix (Intensity)



Gambar 7. Confusion Matrix (Advanced)

E. Analisis Grad-CAM

Visualisasi Grad-CAM digunakan untuk memastikan model melakukan prediksi berdasarkan area anatomi yang benar. Pada skenario baseline dan geometric, fokus model cenderung tepat berada pada area paru, terutama di bagian hilus dan lapangan paru bawah. Namun, pada skenario intensity, model menunjukkan area aktivasi yang lebih menyebar akibat gangguan noise dan perubahan intensitas, sehingga meningkatkan peluang kesalahan klasifikasi. Sebaliknya, skenario advanced menunjukkan pola aktivasi yang lebih terarah dan kompak pada area paru, mengindikasikan generalisasi fitur yang lebih baik. Visualisasi Grad-CAM untuk tiga model pada contoh citra Normal dan Tuberculosis ditampilkan pada Gambar 8.



Gambar 8. Visualisasi Grad-CAM pada 3 Model Representatif

F. Analisis Statistik

Hasil akurasi tinggi pada skenario advanced perlu divalidasi secara statistik untuk memastikan peningkatan performa tidak terjadi secara kebetulan. Oleh karena itu, dua metode diterapkan:

a. Bootstrap Confidence Interval (CI)

Bootstrap CI (95%) menunjukkan bahwa seluruh metrik pada skenario advanced memiliki rentang sempit, menandakan stabilitas tinggi. Misalnya, interval akurasi berada pada [0.978, 0.992], lebih sempit dibandingkan tiga skenario lain. Hasil Bootstrap CI untuk keempat model disajikan pada Tabel 3.

Tabel 3. Hasil Bootstrap Confidence Interval (CI95)

Model	F1-Score	CI 95% Bawah	CI 95% Atas	Keterangan
Advanced Augmentation	0.9569	0.9389	0.975	F1-Score dan stabilitas terbaik.
Baseline (No Aug)	0.9484	0.9298	0.967	F1-Score tinggi, stabilitas baik.
Geometric Aug	0.939	0.9198	0.9581	F1-Score sedikit lebih rendah, stabilitas baik.
Intensity Aug	0.9187	0.8953	0.9421	F1-Score terendah, CI terlebar (stabilitas terburuk).

b. Uji McNemar

Uji McNemar digunakan untuk membandingkan perbedaan prediksi antar model. Hasilnya menunjukkan tidak terdapat perbedaan signifikan antara model advanced dan baseline ($p > 0.05$), meskipun model advanced unggul secara numerik. Hasil Uji McNemar untuk keempat model disajikan pada Tabel 4.

Tabel 4. Hasil Uji McNemar Antar Model

Model A	Model B	χ^2 Statistic	p-value	Keterangan
Advanced Aug	Baseline	2.25	0.1336	Tidak signifikan
Advanced Aug	Geometric Aug	2.25	0.1336	Tidak signifikan
Advanced Aug	Intensity Aug	0.125	0.7237	Tidak signifikan
Baseline	Geometric Aug	0.25	0.6171	Tidak signifikan
Baseline	Intensity Aug	0.9	0.3428	Tidak signifikan
Geometric Aug	Intensity Aug	0.9	0.3428	Tidak signifikan

Kinerja advanced lebih tinggi, tetapi peningkatannya belum cukup kuat secara statistik untuk menyimpulkan perbedaan signifikan.

G. Pembahasan

Hasil penelitian menunjukkan bahwa augmentasi data memiliki pengaruh penting terhadap kinerja model deep learning pada klasifikasi Tuberkulosis menggunakan citra X-ray. Teknik augmentasi lanjutan (MixUp,

CutMix, Random Erasing) terbukti memberikan kinerja tertinggi, sejalan dengan literatur terbaru yang menekankan efektivitas teknik ini dalam meningkatkan robustness model pada citra medis. Meskipun demikian, peningkatan performa tersebut tidak selalu signifikan secara statistik. Hal ini dapat disebabkan oleh:

- 1) Dataset yang relatif kecil sehingga perbedaan antar model tidak selalu konsisten.
- 2) Kelas TB yang lebih sedikit, membuat perubahan kecil dalam prediksi berdampak besar pada perhitungan statistik.
- 3) Karakteristik citra X-ray yang cenderung homogen sehingga augmentasi sederhana sudah memberikan efek yang cukup.

Hasil penelitian ini konsisten dengan studi sebelumnya yang melaporkan bahwa augmentasi data dapat meningkatkan kinerja model deep learning pada klasifikasi citra medis. Penelitian [7] menunjukkan bahwa augmentasi geometrik mampu meningkatkan akurasi model DenseNet, namun peningkatannya terbatas. Sementara itu, [12] melaporkan bahwa augmentasi intensitas berpotensi menurunkan sensitivitas terhadap pola patologis halus apabila diterapkan secara berlebihan, sejalan dengan penurunan recall pada skenario intensity dalam penelitian ini. Lebih lanjut, studi [13] menunjukkan bahwa teknik augmentasi lanjutan seperti MixUp dan CutMix meningkatkan robustness dan generalisasi model pada dataset tidak seimbang. Temuan tersebut sejalan dengan hasil penelitian ini, di mana skenario advanced augmentation menghasilkan F1-score, AUROC, dan AUPRC tertinggi serta jumlah false negative yang lebih rendah, meskipun peningkatannya belum signifikan secara statistik berdasarkan uji McNemar.

Secara umum, penelitian ini mengonfirmasi bahwa augmentasi data tetap menjadi strategi penting untuk meningkatkan generalisasi model dalam lingkungan klinis. Namun, diperlukan dataset yang lebih besar atau validasi cross-dataset untuk memastikan generalisasi yang kuat

IV. Kesimpulan dan saran

Berdasarkan hasil penelitian ini, menunjukkan bahwa teknik augmentasi data memiliki pengaruh penting terhadap kinerja DenseNet121 dalam klasifikasi Tuberkulosis pada citra X-ray, di mana skenario Advanced Augmentation (MixUp, CutMix, dan Random Erasing) memberikan performa numerik terbaik dengan akurasi 98.57%, F1-score 0.9569, serta fokus Grad-CAM yang lebih terarah pada area patologis dibandingkan skenario Baseline, Geometric, dan Intensity. Meskipun demikian, uji statistik (Bootstrap CI dan McNemar) menunjukkan bahwa peningkatan performa pada skenario Advanced belum signifikan pada tingkat $\alpha = 0.05$, sehingga keunggulannya bersifat empiris namun belum dapat dikonfirmasi secara statistik. Secara keseluruhan, Advanced Augmentation tetap menjadi teknik yang paling menjanjikan dalam meningkatkan sensitivitas, robustness, serta kualitas generalisasi model, namun diperlukan dataset yang lebih besar atau evaluasi lintas domain untuk memastikan signifikansi dan konsistensi peningkatan kinerjanya.

Penelitian selanjutnya disarankan untuk mengoptimalkan teknik Advanced Augmentation melalui eksplorasi parameter yang lebih adaptif, serta mengintegrasikan pendekatan berbasis interpretabilitas seperti Attention-Guided CNN atau region-focused learning guna meningkatkan ketepatan area perhatian model. Evaluasi lintas dataset dari berbagai sumber dan perangkat radiografi diperlukan untuk memastikan kemampuan generalisasi model pada kondisi klinis yang beragam. Selain itu, penggunaan metode statistik yang lebih komprehensif, seperti Bayesian inference atau permutation testing, direkomendasikan untuk memperoleh pemahaman yang lebih kuat mengenai signifikansi perbedaan performa antar-model. Perluasan ukuran dataset dan validasi eksternal juga penting dilakukan agar peningkatan kinerja yang diamati dapat dibuktikan secara signifikan dan mendukung penerapan model secara praktis pada sistem pendukung diagnosis Tuberkulosis.

Ucapan Terima Kasih (Opsional)

Penulis mengucapkan terima kasih kepada STMIK IKMI Cirebon atas dukungan fasilitas dan bimbingan akademik selama proses penelitian ini. Penghargaan juga disampaikan kepada dosen pembimbing yang telah memberikan arahan, masukan konstruktif, serta pendampingan yang intensif sehingga penelitian ini dapat diselesaikan dengan baik. Selain itu, penulis berterima kasih kepada penyedia dataset Tuberculosis Chest X-Ray pada platform Kaggle yang memungkinkan penelitian ini dilaksanakan. Semua pihak yang telah membantu, baik secara langsung maupun tidak langsung, penulis ucapkan terima kasih.

Daftar Pustaka

- [1] A. U. Ibrahim, E. Guler, M. Guvenir, K. Suer, S. Serte, and M. Ozsoz, "Automated detection of Mycobacterium tuberculosis using transfer learning," *J Infect Dev Ctries*, vol. 15, no. 5, pp. 678–686, May 2021, doi: 10.3855/JIDC.13532.
- [2] S. Hansun and et al., "A systematic review of deep learning approaches for tuberculosis detection on chest radiography," *Healthcare*, 2023.
- [3] A. N. Marginean *et al.*, "Reliable learning with PDE-based CNNs and densenets for detecting COVID-19, pneumonia, and tuberculosis from chest X-ray images," *Mathematics*, vol. 9, no. 4, pp. 1–20, Feb. 2021, doi: 10.3390/math9040434.
- [4] Y. Kateb, H. Megloui, and A. Khebli, "Coronavirus Diagnosis Based on Chest X-Ray Images and Pre-Trained DenseNet-121," *Revue d'Intelligence Artificielle*, vol. 37, no. 1, pp. 23–28, Feb. 2023, doi: 10.18280/ria.370104.
- [5] K. Ann, Y. Jang, H. Shim, and H. J. Chang, "Multi-Scale Conditional Generative Adversarial Network for Small-Sized Lung Nodules Using Class Activation Region Influence Maximization," *IEEE Access*, vol. 9, pp. 139426–139437, 2021, doi: 10.1109/ACCESS.2021.3116034.
- [6] S. Korevaar *et al.*, "Incidental detection of prostate cancer with computed tomography scans," *Sci Rep*, vol. 11, no. 1, Dec. 2021, doi: 10.1038/s41598-021-86972-y.
- [7] E. Goceri, "Medical image data augmentation: techniques, comparisons, and interpretations," *Artif Intell Rev*, 2023.
- [8] R. Shetty and P. N. Sarapadi, "Adaptive data augmentation training based attention regularized densenet for diagnosis of thoracic diseases," *Indian Journal of Computer Science and Engineering*, vol. 12, no. 4, pp. 1055–1064, Jul. 2021, doi: 10.21817/indjcs/2021/v12i4/211204207.
- [9] A. Shati, A. Datta, A. Mansoor, and G. M. Hassan, "ETDHDNet: An advanced DenseNet-based extended texture descriptor for efficient tuberculosis prediction in CXR images," *Intell Based Med*, vol. 12, Jan. 2025, doi: 10.1016/j.ibmed.2025.100269.
- [10] D. Husen, "Evaluasi Teknik Augmentasi Data untuk Klasifikasi Tumor Otak Menggunakan CNN pada Citra MRI," 2024. doi: <https://doi.org/10.46764/teknimedia.v5i2.220>.
- [11] W. Chokchaithanakul, P. Punyabukkana, and E. Chuangsuwanich, "Adaptive Image Preprocessing and Augmentation for Tuberculosis Screening on Out-of-Domain Chest X-Ray Dataset," *IEEE Access*, vol. 10, pp. 132144–132152, 2022, doi: 10.1109/ACCESS.2022.3229591.
- [12] C. Shorten and T. M. Khoshgoftaar, "Data augmentation for medical imaging: A systematic review," *Med Image Anal*, 2022.
- [13] X. Liu and et al., "Data augmentation and generalization in medical imaging: a review," *J Imaging*, 2023.